

Classificação de Sons Cardíacos usando *motifs* **Desenvolvimento de uma aplicação móvel**

Soraia Carvalho da Cruz Oliveira

**Dissertação para obtenção do Grau de Mestre em Engenharia
Informática, Área de Especialização em Tecnologias do Conhecimento e
Decisão**

Orientador: Elsa Maria de Carvalho Ferreira Gomes

Porto, Outubro de 2014

Resumo

Este documento foi redigido no âmbito da Tese, do Mestrado em Engenharia Informática na área de Tecnologias do Conhecimento e Decisão, do Departamento de Engenharia Informática, do ISEP, cujo tema é classificação de sons cardíacos usando *motifs*.

Neste trabalho, apresenta-se um algoritmo de classificação de sons cardíacos, capaz de identificar patologias cardíacas. A classificação do som cardíaco é um trabalho desafiante dada a dificuldade em separar os sons ambiente (vozes, respiração, contacto do microfone com superfícies como pele ou tecidos) ou de ruído dos batimentos cardíacos.

Esta abordagem seguiu a metodologia de descoberta de padrões SAX (*motifs*) mais frequentes, em séries temporais relacionando-os com a ocorrência sistólica (S1) e a ocorrência diastólica (S2) do coração. A metodologia seguida mostrou-se eficaz a distinguir sons normais de sons correspondentes a patologia. Os resultados foram publicados na conferência internacional IDEAS'14 [Oliveira, 2014], em Julho deste ano.

Numa fase seguinte, desenvolveu-se uma aplicação móvel, capaz de captar os batimentos cardíacos, de os tratar e os classificar. A classificação dos sons é feita usando o método referido no parágrafo anterior. A aplicação móvel, depois de tratar os sons, envia-os para um servidor, onde o programa de classificação é executado, e recebe a resposta da classificação.

É também descrita a arquitetura aplicacional desenhada e as componentes que a constituem, as ferramentas e tecnologias utilizadas.

Palavras-chave: Sons cardíacos, Patologia, Coração, Classificação, Padrões, Motifs.

Abstract

This document was prepared as part of the Thesis of the MSc in Computer Science in the area of Knowledge and Decision Technologies, Department of Computer Engineering, ISEP. The theme is classification of heart sounds.

In this dissertation we present an algorithm for heart sounds classification, able to identify cardiac pathologies. The classification of the heart sound is a challenging work due to the difficulty in separating heartbeat sound from the ambient sounds (voices, breathing, microphone contact with surfaces like skin or textiles) or noise.

In this approach we use the methodology of discovery of frequent SAX patterns (motifs) in time series, relating them with systolic (S1) and diastolic (S2) heart events. The methodology was effective to distinguish normal sounds from pathologic sounds. The results were published in international conference IDEAS'14 [Oliveira, 2014], in July.

We have also developed a mobile application, able to capture, process and classify heart beats. The mobile application, captures and processes the sounds, sends them to a server where the classification program is running, and receives the classification result.

We also described the application architecture, its components as well as the tools and technologies used.

Keywords: Heart Sounds, Pathologies, Heart, Classification, Motifs.

Agradecimentos

Agradeço a todas as pessoas que de alguma forma intervieram na realização desta investigação.

Um agradecimento com especial atenção ao trabalho, ajuda, interesse e motivação transmitida pela Professora Elsa Gomes, que me acompanhou, estando sempre disponível para me apoiar, esclarecendo, em qualquer circunstância, todas as dúvidas que me surgiram e apoiando na solução ao longo destes meses de trabalho.

Gostaria de agradecer aos meus pais, aos meus sogros e restante família pela presença deles nos momentos importantes da minha vida e ainda agradecer com carinho ao meu marido Rui Oliveira pelo empenho, apoio, motivação e amizade demonstrada ao longo deste caminho.

Índice

1	Introdução	18
1.1	Descrição do projecto	18
1.2	Motivação	19
1.3	Objectivo e contribuições	19
1.4	Estrutura da dissertação	20
2	Estado da arte	22
2.1	Sons cardíacos	22
2.2	Dataset	23
2.3	Abordagens anteriores.....	25
2.3.1	Abordagem baseada na detecção de Picos.....	25
2.3.2	Abordagem baseada em <i>motifs</i> multi-resolução de séries temporais	27
2.4	Aplicações Móveis - Captação de sons cardíacos	30
2.4.1	Aplicação de baixo custo para monitorização de sons cardíacos	30
3	Ferramentas e Tecnologias.....	35
3.1	Java	35
3.2	Android	35
3.3	Maven.....	36
3.4	SOAP	36
3.5	Netbeans	36
3.6	Eclipse e ADT.....	36
3.7	Adobe Fireworks	37
4	Segmentação e Classificação de sons cardíacos	38
4.1	Algoritmo de Classificação.....	38
4.1.1	Classificação do sinal cardíaco	40
4.1.2	Discussão de resultados	41
5	Aplicação móvel para classificação de sons cardíacos	44
5.1	Arquitectura	44
5.1.1	Cliente-Servidor.....	45
5.2	Aplicação Móvel	47
5.3	Record Heartbeat	48
5.3.1	Load File	50
5.3.2	Webservices	53
6	Conclusão	54

6.1	Trabalho Futuro.....	55
7	Referências	57

Lista de Figuras

Figura 1: coração humano [Heart, 2014]	22
Figura 2: sístole e diástole [Heart, 2014].....	23
Figura 3: o sistema DigiScope Collector [Pereira, 2011]	24
Figura 4: localização do S1 (lub) e S2 (dub) no ao longo do tempo, por classe.	24
Figura 5: duas amostras de som cardíaco do dataset	25
Figura 6: detecção dos Picos no sinal de som cardíaco.....	27
Figura 7: discretização de uma serie temporal através do SAX	28
Figura 8: padrões de tamanho 40 encontrados num ficheiro de audio (x-Tempo/y-Amplitude)	29
Figura 9: imagem 1: Sinal original; imagem 2: Envelope e picos de sinal; imagem 3: Sinal original e picos de sinal; imagem 4: Exemplo de padrões alternados a azul e vermelho ao longo da serie temporal (X -Tempo / Y-Amplitude).	30
Figura 10: dispositivo e aplicação Unborn Heart [Unborn].....	31
Figura 11: doppler para captar sons cardíacos com cabo para gravação em smartphone [Device].....	32
Figura 12: diagrama de blocos do hardware do DRM [Mittra, 2009].	33
Figura 13: novo algoritmo de classificação	41
Figura 14: arquitectura applicacional cliente-servidor utilizada no desenvolvimento	45
Figura 15: funcionamento da arquitectura cliente-servidor	46
Figura 16: interface principal da aplicação móvel.....	47
Figura 17: botão “Start Record” permite o início da gravação do som cardíaco	48
Figura 18: aplicação de filtros e normalização ao sinal cardíaco gravado	49
Figura 19: quarto e último passo no processo de classificação	50
Figura 20: lista de ficheiros CSV apresentada para carregamento na aplicação	51
Figura 21: botão para obter a classificação do som cardíaco	52

Lista de Tabelas

Tabela 1: resultado da medição comparativa [Mittra, 2009].	34
Tabela 2: comparação de resultados obtidos na antiga e na nova abordagem	42

Acrónimos e Símbolos

Lista de Acrónimos

CSV	<i>Comma Separated Values</i>
SAX	<i>Symbolic Aggregate ApproXimation</i>
APP	<i>Application</i>
RHP	<i>Real Hospital Portuguese</i>
Wi-Fi	<i>Wireless Fidelity</i>
DRM	<i>Detection and Recording Module</i>
MP3	<i>MPEG Layer 3</i>
USB	<i>Universal Serial Bus</i>
IDE	<i>Integrated Development Environment</i>
SOAP	<i>Simple Object Access Protocol</i>
XML	<i>EXtensible Markup Language</i>

1 Introdução

A saúde pública é uma área que exige uma elevada quantidade de investigação contínua, na esperança de encontrar melhores soluções para as várias patologias inerentes ao Homem. Várias áreas, para além das ciências humanas podem dar o seu contributo e facilitar a vida dos técnicos, médicos e os demais, que no seu dia-a-dia lidam com os vários sintomas provocados pelos diferentes problemas de saúde dos seus pacientes.

A nível mundial existe uma elevada quantidade de iniciativas dedicadas a recolher e disponibilizar tecnologia dedicada à saúde que nos permite melhorar a qualidade de vida e acelerar processos. Neste âmbito, surge a investigação de reconhecimento de patologias do coração através de sons cardíacos, que visa apoiar e facilitar o trabalho dos médicos e especialistas do coração, atribuindo-lhes mobilidade na realização do seu trabalho.

A identificação automática de patologias cardíacas, analisando os atributos dos sons cardíacos gravados, é um problema desafiante dada a variabilidade das características das gravações de sons cardíacos, o ruído existente nas gravações e a subtilidade nas diferenças das condições cardíacas.

O problema torna-se mais complicado quando os sons cardíacos são obtidos a partir de dispositivos móveis, em diferentes tipos de ambiente, como por exemplo, em hospitais ou rastreios na rua. A capacidade de classificar automaticamente ou apoiar na decisão da classificação de sons cardíacos poderá contribuir para a melhoria de cuidados médicos, em particular em locais onde o acesso a unidades especializadas é mais difícil.

1.1 Descrição do projecto

Este trabalho surge na sequência de trabalhos que têm vindo a ser desenvolvidos com o objectivo de definir algoritmos capazes de realizar o rastreio de patologias cardíacas, de

primeiro nível, quer num ambiente hospitalar acompanhado por um médico usando um estereoscópio digital ou um telemóvel.

Assim, numa primeira fase (servidor), pretendia-se desenvolver um algoritmo capaz de, perante o novo som cardíaco adquirido, identificar correctamente a situação clínica (ou classe). Neste caso, foram consideradas três classes: Normal (N), Murmur (M) and Extrasystole (E). Na categoria normal estão os sons correspondentes a um coração saudável e, nas outras duas, os sons correspondentes a um coração com patologia.

Na fase seguinte foi desenvolvida uma aplicação móvel que permite ao utilizador captar sons cardíacos através de um smartphone para posterior classificação.

1.2 Motivação

A principal motivação para a escolha do tema da investigação foi ajudar os profissionais de saúde, da área das doenças cardíacas, através da utilização de aplicações móveis. Este trabalho permitiu também à autora aprofundar o seu conhecimento sobre a relação entre a computação móvel e a saúde.

Esta investigação além do desenvolvimento para o alcance de melhores resultados na classificação de patologias cardíacas, também completa de forma inovadora (oferece mobilidade) o trabalho já realizado anteriormente em prol de uma solução para a caracterização de patologias cardíacas através da captação de som, o que faz também parte da lista de motivações da autora.

O facto de poder desenvolver um algoritmo de classificação dedicado, o que requer um conhecimento aprofundado sobre o funcionamento do coração, foi um dos pontos fulcrais, e ainda a capacidade de construir algo que apesar de ser mais útil para cardiologistas pode ajudar no despiste de patologias do coração sendo utilizado por um médico de clínica geral, técnicos ou até mesmo pelo próprio paciente, que utilizando a aplicação móvel a partir de casa pode perceber se o funcionamento do seu coração é normal ou portador de uma patologia, o que pode contribuir para um diagnóstico precoce de problemas cardíacos.

1.3 Objectivo e contribuições

O sistema de caracterização de patologias cardíacas, descrito neste trabalho, tem por objectivo capturar sons cardíacos e classificá-los usando um modelo de classificação baseado na estrutura de sinais do tipo cardíaco. Esta recolha de sinal é realizada através de uma aplicação móvel e a classificação é finalizada num servidor web, que recebe dados da aplicação e retorna a caracterização associada ao sinal.

Esta investigação surge no âmbito da unidade curricular Tese, componente do Mestrado em Engenharia Informática, ramo de Tecnologias do Conhecimento e Decisão, do Instituto Superior de Engenharia do Porto, e tem como tema Classificação de Sons Cardíacos usando *motifs*.

As principais contribuições e resultados atingidos com este trabalho são os seguintes:

- Um novo algoritmo de classificação;
- Uma aplicação móvel desenvolvida na plataforma de sistemas móveis Android e respectivo servidor capaz de classificar os sons cardíacos;
- Os resultados obtidos por este novo modelo de classificação foram publicados na Conferência IDEAS'14, "18th International Database Engineering & Applications Symposium" [Oliveira, 2014].

1.4 Estrutura da dissertação

No primeiro capítulo da dissertação, intitulado de *Introdução*, é feita uma introdução relativamente à investigação que foi realizada, para que o leitor se situe no contexto da mesma. Assim, ao ler este capítulo, o leitor irá perceber quais as motivações e objectivos perante este trabalho e adquirir conhecimento sobre o tema e projecto desenvolvido.

No segundo capítulo, *Estado da Arte*, é feita uma análise a um conjunto de soluções e investigações elaboradas anteriormente a este trabalho. Desta forma, ao apresentar as diferentes abordagens faz-se, também neste capítulo, uma análise aos resultados das mesmas. Também se comparam as metodologias seguidas com alguns trabalhos publicados.

No terceiro capítulo, *Aplicação móvel para classificação de sons cardíacos*, são apresentados os detalhes da implementação e do desenvolvimento da aplicação móvel e dos serviços web.

No capítulo quatro, *Segmentação e Classificação de sons cardíacos*, é apresentado o programa de servidor que permite a segmentação e a classificação dos sons cardíacos. É neste capítulo que é apresentado o algoritmo de classificação desenvolvido pela autora.

No capítulo cinco, *Ferramentas e Tecnologias*, são descritas as ferramentas e tecnologias usadas neste trabalho de investigação.

No capítulo seis, *Conclusão*, como é implícito, são feitas as conclusões finais ao trabalho desenvolvido. As conclusões referidas neste capítulo foram sendo extraídas ao longo dos testes no âmbito da investigação. Ainda no mesmo capítulo são apresentadas as ideias e o planeamento para o futuro desenvolvimento deste projecto.

No capítulo sete, *Referências*, encontram-se expostas as fontes que foram consultadas para a realização desta dissertação e que lhe serviram de suporte.

2 Estado da arte

2.1 Sons cardíacos

Nesta seção faz-se uma breve abordagem à fisiologia do coração humano e uma descrição dos sons cardíacos.

O coração humano é composto por quatro câmaras de músculo cardíaco (miocárdio). As duas câmaras superiores (aurículas) têm como principal função receber o sangue para posteriormente o injectar nas duas câmaras inferiores (ventrículos). A aurícula e o ventrículo direito recebem o sangue proveniente de todo o corpo, rico em dióxido de carbono e bombeiam-no para os pulmões. A aurícula e o ventrículo esquerdo recebem o sangue rico em oxigénio proveniente dos pulmões e bombeiam-no para todo o corpo. Quatro válvulas garantem que o fluxo sanguíneo seja unidireccional. As válvulas tricúspide e bicúspide permitem que o sangue apenas flua das aurículas para os ventrículos, evitando o retrocesso.

O sangue flui dos ventrículos para fora do coração pelas artérias aorta e pulmonar.




Figura 1: coração humano [Heart, 2014]

À medida que a pressão ventricular excede a pressão na artéria pulmonar (lado direito do coração) ou na artéria aorta (lado esquerdo do coração), o sangue é forçado a sair do ventrículo, mantendo-se fechadas as válvulas tricúspide e mitral, de forma a não permitir o refluxo para as aurículas. Esta fase de contração no ciclo cardíaco é conhecida como sístole.

A turbulência causada pelo fecho das válvulas mitral e tricúspide no início da sístole produz S1 (ou lub), o som do coração que marca o início da sístole.

Quando os músculos ventriculares relaxam, a pressão no interior destas diminui até ser inferior à das aurículas, promovendo a abertura das válvulas atrioventriculares e o reenchimento dos ventrículos. No início desta fase, a diástole, é produzido o segundo som cardíaco, S2 (ou dub), causado pelo fecho das válvulas pulmonar e aórtica. Estes são os sons do coração produzidos por uma pessoa adulta normal [Heart, 2014].




Figura 2: sístole e diástole [Heart, 2014]

Outros sons produzidos pelo coração, tais como murmúrios, S3 e S4, estão frequentemente relacionados com um coração especial, com patologia [Karnath, 2010].

2.2 Dataset

O dataset é composto por 312 gravações de sons cardíacos resultantes de auscultações efetuadas com o DigiScope Collector (Figura 3). Estes sons foram captados na unidade de Cardiologia Unidade Materno-Fetal do Hospital Real Português no Recife, Brasil (Pereira, 2011). Cada gravação contém 6 a 10 segundos gravados de auscultação cardíaca em crianças. Foram também anotadas, pelos clínicos do RHP, informações relativas ao paciente. Cada gravação foi catalogada com uma das três classes: Normal, Murmur e Extrasystole. A classe Normal (N) tem uma contagem de 200, a classe Murmur (M) conta 66 casos e a Extrasystole (E) 46.

Nos ficheiros da classe Normal, os sons cardíacos registados pertencem a indivíduos saudáveis. Um som cardíaco normal define-se pelo claro “lub dub lub dub”, em que o tempo “lub dub” é menor do que “dub lub”, em indivíduos adultos em repouso onde o ritmo cardíaco varia entre os 60 e os 100 batimentos por minuto (ver Figura 4).

No entanto, como este conjunto de dados foi recolhido num grupo de crianças, de idades diversas, o ritmo cardíaco varia entre os 40 e os 140 batimentos por minuto. Na classe Murmur, o som cardíaco contém um Murmur entre o “lub dub” ou entre “dub lub”, mas nunca em simultâneo. Por último, nos ficheiros de som referentes à classe “Extrasystole” existe um tipo de som que se encontra fora do ritmo envolvendo batimentos cardíacos extra

(ou o inverso), como “lub-lub dub” ou “lub dub-dub”. Esta categoria ocorre muito frequentemente em crianças e ocasionalmente em adultos, podendo não determinar uma patologia [Bentley,2011].



Figura 3: o sistema DigiScope Collector [Pereira, 2011]

Estes sons, recolhidos em situações do mundo real, contêm vários tipos de ruído como ruído ambiente, a respiração do paciente, o movimento do microfone contra a pele ou na roupa. As diferenças entre os sons do coração correspondem a diferentes sintomas cardíacos também pode ser extremamente subtil e difícil de identificar.

Os ficheiros áudio do dataset são de comprimento variável, entre 1 segundo e 30 segundos. Na Figura 5, apresentam-se duas amostras diferentes de sons no dataset. Alguns foram cortados para reduzir o ruído excessivo e proporcionar o fragmento saliente do som [Bentley,2011].

Dataset B	Caracterização dos Sons
Normallub...dub.....lub...dub.....lub...dub.....lub...dub.....
Murmur	...lub..****...dub..... lub..****..dub lub..****..dub Ou ...lub..... dub...*****...lub dub...*****...lubdub...
Extrasystole	...lub.....dub.....lub.....dub.....lub.lub.....dub..... Ou ...lub.....dub.....lub.....dub.dub.....lub.....dub....

Figura 4: localização do S1 (lub) e S2 (dub) no ao longo do tempo, por classe.




Figura 5: duas amostras de som cardíaco do dataset

2.3 Abordagens anteriores

O presente trabalho insere-se num projeto mais vasto que tem vindo a ser desenvolvido, tendo já passado por diferentes abordagens, com resultados publicados. Nesta secção faz-se uma breve descrição dessas abordagens.

2.3.1 Abordagem baseada na detecção de Picos

A primeira fase do trabalho foi realizada com o objectivo de participar no concurso “PASCAL Classifying Heart Sounds Challenge” [Bentley, 2011] cujo principal desafio consistia em identificar patologias cardíacas através de sons captados através de um estetoscópio digital e através de smartphones (fonocardiograma) [Gomes, 2012]. A metodologia utilizada foi a imposta pelo concurso que avaliava os resultados obtidos pelos candidatos no final de duas etapas. A primeira etapa, consistia na segmentação dos sons cardíacos (S1 e S2) e a segunda etapa, na classificação dos mesmos. O dataset descrito na secção 2.2 foi um dos dois datasets (dataset B) disponibilizados no âmbito do concurso. Para além do dataset B já referido, existia o dataset A, composto por um conjunto de dados captados através de uma aplicação que simula um estetoscópio em iOS [Palm *et al*, 2010].

2.3.1.1 Segmentação de sons cardíacos

O objectivo da primeira fase do concurso consistia no desenvolvimento de um método para determinar a localização de S1 e S2 (picos) nos ficheiros de áudio (primeira imagem da Figura 6), segmentando os sons cardíacos do tipo Normal dos *datasets*.

Os ficheiros de áudio foram pré-processados antes de realizar a segmentação. No pré-processamento utilizaram-se técnicas de reamostragem (*decimate*) e um filtro passa-banda Chebyshev tipo I de 5ª ordem com frequência de corte inferior de 100Hz e frequência de corte superior de 882 Hz (segunda imagem da Figura 6). O sinal foi normalizado relativamente ao valor máximo absoluto. Após o processo de normalização foi calculado o envelope Shannon, seguindo o cálculo da média da energia Shannon realizado ao longo de uma janela contínua de 0.02 segundos com 0.01 segundo de sobreposição [Liang et al., 1997]. Os picos S1 e S2 são identificados nesta onda normalizada através de uma função em Matlab [Matlab] que encontra os valores máximos de onda áudio (terceira imagem da Figura 6), os picos. Usando esta estratégia, segmentaram-se a maioria dos sons cardíacos [Gomes, 2013a].

A estratégia de usar a segmentação antes da classificação do sinal de sons cardíacos é frequentemente encontrada na literatura. Por exemplo, Groch propôs uma metodologia onde a segmentação se baseava nas características de sinal no domínio do tempo [Groch et al., 1992]. Strunic, usou estratégias de extracção de sinal de determinada banda para reduzir anomalias e definir um *threshold* na amplitude para escolher os pontos e efectuar a segmentação [Strunic et al., 2007]. Mais recentemente, Marques et al. utilizaram *wavelets* na segmentação [Marques, 2013].

2.3.1.2 Classificação dos sons cardíacos

O objetivo da primeira fase do concurso consistia em encontrar uma metodologia capaz de classificar um conjunto de sons cardíacos não classificados (*Unlabelled*) em uma das classes de cada conjunto de dados (Normal, Murmur e Extrasystole no caso do dataset B).

A metodologia seguida baseou-se nas distâncias entre S1 e S2. Em primeiro lugar, procurou-se realizar a deteção dos sons S1 e S2 baseado no facto de que S2 ser maior que S1, para batimentos cardíacos normais [Kumar, 2006]. A distância entre S1 e S2 foi calculada e comparada para cada segmento [Gupta, 2007]. Considerou-se que o maior intervalo entre dois sons correspondia à diástole e o som do lado direito foi designado como S1 e o som do lado esquerdo foi designado como S2. Infelizmente, estes intervalos variam muito de ficheiro para ficheiro, no nosso dataset (Figura 5), devido a tratar-se de sons cardíacos de crianças de diferentes idades, com diferentes taxas de coração.

Após identificar os atributos, extraídos a partir das distâncias entre S1 e S2 (médias, medianas e desvios padrão) utilizaram-se os algoritmos de classificação J48, que gera árvores de decisão, e o Multi Layer Perceptron (MLP) usando o Weka [Witten and Frank, 2005].

Esta metodologia, sugerida por Liang [Liang, 1997] foi também utilizada por alguns autores como Kumar [Kumar, 2006] e Gupta [Gupta, 2007]. Na literatura encontram-se outras propostas de classificação para classificar os sons cardíacos. Por exemplo, Karraz extraiu o QRS dos sinais e utilizou-os construir uma rede neuronal (*Neural Network*) e classificou os sinais baseado numa ferramenta Bayesiana [Karraz, 2006]. Babaei, também usou *Neural Network* e *Discrete Wavelet Transform* [Babaei, 2009]. Kampouraki usou *Support Vector Machines* (SVMs) para classificar ecocardiogramas (ECG) [Kampouraki, 2009]. Kao, usou SVM para classificar sinais PCG, após segmentação [Kao, 2011].




Figura 6: detecção dos Picos no sinal de som cardíaco

Os resultados alcançados com esta metodologia, avaliados para um conjunto de teste escondido aos participantes do concurso, conseguiram resultados interessantes (ganhou o concurso). Apresenta, porém dificuldade em classificar determinados sons não normais.

2.3.2 Abordagem baseada em *motifs* multi-resolução de séries temporais

Dadas as limitações da abordagem descrita na secção 2.3.1 na classificação de sons cardíacos não normais optou-se por uma abordagem completamente diferente. A ideia é encontrar padrões (*motifs*) frequentes nas séries temporais de sons cardíacos usando um algoritmo de extração de padrões frequentes [Ferreira, 2006]. Estes padrões (ou *motifs*) são considerados como atributos [Gomes, 2013]. Um *motif* numa série temporal é uma subsequência frequentemente repetida (ver Figura 7). Para encontrar os padrões mais

comuns e mais relevantes utilizamos o algoritmo Multiresolution Motif Discovery (MrMotif) para séries temporais [Castro, 2010b]. Este algoritmo usa a metodologia SAX (Symbolic Aggregate approXimation) [Lin, 2002] para discretizar os sinais e procurar padrões nas sequências resultantes.




Figura 7: discretização de uma serie temporal através do SAX

A técnica utilizada baseia-se na observação e descoberta de padrões num sinal ao longo de séries temporais, em que segmentos de sinal são observados, e padrões relevantes são caracterizados através de uma palavra SAX. A segmentação através de padrões permite que a classificação dos mesmos possa no final ser feita com base no grupo de padrões semelhante entre o conjunto de dados utilizados. O SAX é uma abordagem simbólica para séries temporais que representa a série contínua como um discretizado e permite a redução de dimensionalidade e indexação. A descoberta de padrões em sinais tem sido utilizada em várias áreas distintas, tais como a saúde e medicina, particularmente em EEG, para a descoberta de padrões como o que poderá anteceder uma convulsão [Yankov, 2007].

Como uma aproximação simbólica, o SAX (T, w, a) converte a série temporal original com tempo real T de comprimento n numa sequência de w (tamanho da palavra em que o SAX transforma o padrão) utilizando símbolos que pertencem a um alfabeto a . Na Figura 7 pode observar-se como pode um segmento de uma serie temporal ser discretizado numa sequência de símbolos SAX utilizando a ferramenta iMotifs [Castro, 2010b], uma interface gráfica para o algoritmo MrMotif, de que falaremos a seguir. Ao tamanho do alfabeto chama-se resolução.

O algoritmo SAX começa por reduzir a dimensionalidade da série temporal, dividindo-a em w segmentos do mesmo (comprimento da palavra) utilizando o algoritmo Piecewise Aggregate Aproximação (PAA). Em seguida, a amplitude das séries de temporais é dividida em intervalos e, um símbolo/palavra é atribuído a cada intervalo. A representação iSAX é uma extensão da clássica do SAX permitindo diferentes resoluções simultâneas da mesma palavra [Gomes, 2013b].

O princípio base do algoritmo MrMotif [Castro, 2010b] está em partir de uma baixa resolução (tamanho do alfabeto utilizado) iSax e depois expandir para resoluções mais altas. Como essa expansão é feita, o número de ocorrências (de um dado cluster) reduz à medida que é dividido para a próxima resolução. Na resolução mais alta, um *cluster* é apenas formado somente se por subsequências desse cluster são muitos semelhantes. A resolução mínima possível para o iSax ($gmin$) é 2 e a máxima ($gmax$) é 64, sendo que é possível utilizar as resoluções 2, 4, 8, 16, 32 e 64 [Castro, 1010].

O objetivo do algoritmo MrMotif é, dada uma base de dados de séries de tempo D , um comprimento de padrão m e um parâmetro K , para cada resolução em ($gmin, gmin \times 2, \dots, gmax$) encontra o top_K da frequência de padrões. Na Figura 8, podem observar-se padrões de tamanho 40 obtidos num dos ficheiros áudio.




Figura 8: padrões de tamanho 40 encontrados num ficheiro de audio (x-Tempo/y-Amplitude)

A descoberta de *motifs* permite descobrir os *motifs* mais frequentes nas series temporais (imagem 4 da Figura 9). No caso dos sons cardíacos, sons diferentes devem corresponder a *motifs* diferentes. A frequência de cada motif nas séries temporais são os atributos utilizados para classificação. No passo seguinte, compararm-se algoritmos de classificação (utilizando o

Weka): Decision Trees, LogisticRegression, Rotation Forest and Random Forest [Gomes, 2013a].




Figura 9: imagem 1: Sinal original; imagem 2: Envelope e picos de sinal; imagem 3: Sinal original e picos de sinal; imagem 4: Exemplo de padrões alternados a azul e vermelho ao longo da serie temporal (X -Tempo / Y-Amplitude).

Esta abordagem obtém melhores resultados quando comparada com a abordagem anterior. Os melhores resultados foram obtidos, em termos de precisão média, utilizando Random Forests [Breiman, 2001]. Este algoritmo de classificação parece ser particularmente apropriado para a abordagem baseada em *motifs*.

2.4 Aplicações Móveis – Captação de sons cardíacos

2.4.1 Aplicação de baixo custo para monitorização de sons cardíacos

É muito importante monitorizar mulheres grávidas com alto risco ou histórico de aborto. Podem acontecer anomalias imprevisíveis durante gravidez, em especial o caso da entrada em trabalho de parto prematuro, que pode ser prevenida com um diagnóstico feito antecipadamente. A monitorização pode ajudar na percepção do estado atual da frequência

cardíaca do bebé e caso o bebé esteja em stress é necessária uma especial atenção médica urgente. Os instrumentos ultra-som são largamente utilizados para este fim, em hospitais, para fins variados, no entanto ainda existe uma lacuna entre as tecnologias existentes e a necessidade dos utilizadores na monitorização fetal segura, conveniente e confiável [Mittra, 2009]. Desta forma foi criada uma aplicação móvel e um dispositivo com a sensibilidade de captar sons cardíacos de um feto (Figura 10).



Figura 10: dispositivo e aplicação Unborn Heart [Unborn]

O sistema de monitorização utilizado para captar o som do coração fetal apresentado acima é composto, basicamente por dois módulos principais:

- Módulo de Detecção e Gravação (DRM)
- Módulo de Processamento e Exibição

O DRM é um pequeno hardware de baixo custo composto de um cone acústico desenvolvido especificamente para o efeito e é constituído por um sensor piezoelétrico, pré-amplificadores, amplificadores de potência, filtros e um gravador de MP3 compatível com ligação USB [Mittra, 2009].

As funções básicas deste módulo são:

- Detecção de som do coração fetal através do abdómen materno e gravação do mesmo num ficheiro de áudio.
- Detecção de ruído externo e gravação noutra canal (Noise Channel).
- Geração de indicações audiovisuais de sinal de som cardíaco fetal.



Figura 11: doppler para captar sons cardíacos com cabo para gravação em smartphone
[Device]

Este doppler tem a capacidade, já referida acima, de perceber se existe ruído externo, o que permite que a captação de sinal seja feita no canal de ruído (Noise Channel), em vez de ser feita através do canal utilizado por defeito, o canal abdominal.

O Canal Abdominal (Figura 12) requer a conversão de vibrações mecânicas para um sinal eléctrico através do microfone. Como o batimento do coração de um feto é fraco foi necessária a utilização de um cone acústico especial, semelhante á caixa de um estetoscópio comum, pois o ar compreendido no cone actua como meio de transmissão entre a membrana e o dispositivo piezoeléctrico. A saída do sensor é fornecida ao pré-amplificador para amplificação elevada do sinal e permite desta forma reduzir o ruído [Mittra, 2009].

Para manter o ruído o mais reduzido possível é utilizado um filtro activo passa-baixo com uma frequência de corte de 200 Hz [Mittra, 2009], valor utilizado baseado no facto da maior parte do espectro sonoro do coração do feto se encontrar abaixo deste limite de frequência. O filtro activo é implementado através da utilização de um amplificador operacional, o IC 741, juntamente com uma resistência e um condensador.

O ruído externo é um problema para o processamento de sinal [Mittra, 2009], assim para ultrapassar este problema algumas técnicas especiais de processamento de sinal são utilizadas na gravação de sinal através do canal de ruído (Figura 12).




Figura 12: diagrama de blocos do hardware do DRM [Mitra, 2009].

O canal de ruído detecta, através de um microfone ao ar livre independente, o ruído externo. Desta forma após a pré-amplificação e filtragem de sinal, os sinais de ruído são registados na memória do dispositivo. É importante destacar o facto de o microfone detectar o canal de som abdominal principalmente proveniente do abdómen da mãe com a capacidade de amortecer o ruído externo.

O dispositivo foi testado com um útero artificial, simulado com sinais gerados através da ferramenta Matlab [Matlab], utilizada para processamento de sinal. Os sinais gerados tinham por base simular todos os ruídos existentes na captação do sinal do coração do feto, tais como o coração e também o sistema respiratório da mãe e ainda a simulação do ruído externo. Após estes testes o dispositivo foi testado também em ambiente clínico na captação de sinais cardíacos de fetos em mulheres grávidas. Foram gravadas mais de 16 amostras de sons cardíacos de fetos em diferentes mulheres, com tempo de gestação entre as 36 e as 40 semanas de gravidez [Mitra, 2009].

Os resultados obtidos em ambos os testes realizados encontram-se apresentados na Tabela 1.

Tabela 1: resultado da medição comparativa [Mittra, 2009].

Subject No	Number of Amplitude Burst from Prototype	Number of Amplitude Burst from Reference Instrument	Number of Missed Amplitude Burst	Number of False Amplitude Burst	Performance Index %
1	260	270	10	0	96.30
2	290	286	0	4	98.60
3	274	280	6	0	97.86
4	278	284	6	0	97.89
5	310	302	0	8	97.35
6	294	298	4	0	98.66
7	290	296	0	6	97.97
8	318	324	0	6	98.15
9	292	290	2	0	99.31
10	312	302	10	0	96.69
11	266	280	0	14	95.00
12	302	306	0	4	98.69
13	286	288	0	2	99.31
14	298	304	0	6	98.03
15	314	310	4	0	98.71
16	304	308	0	4	98.70

Os resultados obtidos na Tabela 1 são bastantes significativos, tendo sido obtida uma média de desempenho de 97% [Mittra, 2009].

3 Ferramentas e Tecnologias

Este capítulo apresenta as várias tecnologias e ferramentas utilizadas no desenvolvimento do projeto. As escolhas a seguir apresentadas vão de encontro com as expectativas criadas para o projeto, e para isso foram utilizados alguns critérios. Desta forma é pretendido que o sistema desenvolvido seja imune a falhas e cumpra todos os objetivos pretendidos.

Assim, existem várias necessidades a que a plataforma criada deve dar resposta.

3.1 Java

Esta linguagem de programação é uma tecnologia livre, portátil que possui imensas bibliotecas para trabalhar em rede [Oracle]. O facto da autora já ter experiência profissional e contacto com esta linguagem também pesou na escolha. O sistema desenvolvido trabalha em rede, e o Java, permite a utilização de várias bibliotecas, o que torna o desenvolvimento bastante acessível.

Sendo portátil esta linguagem permitiu que ao longo do desenvolvimento do projeto, ao existirem alterações de cenário, a solução continue operável, salvo raras exceções.

3.2 Android

Linguagem de programação para criação de aplicações móveis desenvolvida pela empresa Google [Android]. Mais de um bilião de dispositivos móveis têm o sistema operativo Android instalado, o que permite que um bilião de dispositivos possa ter uma aplicação desenvolvida com a linguagem de programação instalada. As aplicações desenvolvidas para Android podem ser instaladas e executadas numa vasta variedade de dispositivos, tais como smartphones, tablets, televisões, relógios, entre outros. O software de desenvolvimento é open source e não há qualquer custo para os programadores desenvolverem para a plataforma móvel Android.

3.3 Maven

Ferramenta de gestão e compreensão de projectos de criação de software que permite gerir aplicações web desenvolvidas na linguagem de programação Java [Maven]. Esta ferramenta permite que o processo de construção seja fácil, fornece um sistema de construção uniforme, orientações para um desenvolvimento com boas práticas de desenvolvimento e permite que a migração de projectos seja transparente para outros recursos [Apache].

3.4 SOAP

SOAP (Simple Object Access Protocol) é um protocolo de comunicação [W3School], em que as suas mensagens têm a estrutura de um documento XML (EXtensible Markup Language) [W3School] na qual o elemento envelope identifica o documento XML como uma mensagem SOAP. Estas mensagens além do envelope têm também um cabeçalho, um elemento no seu corpo que tem a informação de chamada ou resposta de um web service e ainda um elemento Fault, onde são apresentadas as mensagens de erro (Ex.: a formação de uma chamada de web service errada).

3.5 Netbeans

O netbeans é um IDE (Integrated Development Environment) [Netbeans] que permite o desenvolvimento de aplicações para serem executadas em computadores, dispositivos móveis e aplicações web. Este ambiente de desenvolvimento integrado permite desenvolver aplicações na linguagem de programação Java, HTML5, PHP, C/C++ e outras. O netbeans é gratuito e open source.

3.6 Eclipse e ADT

O Eclipse é um IDE que através da instalação do plugin ADT (Android Developer Tools) [Developer] permite o desenvolvimento de aplicações para a plataforma móvel Android. O Eclipse é uma plataforma que foi criada com o objectivo de desenvolvimento de aplicações web integradas e desenvolvimento de ferramentas. A plataforma ajuda a ter um rápido desenvolvimento de recursos integrados com base num modelo de instalação de plugins, o que permite obter várias funcionalidades que não fazem parte do Eclipse após a instalação do mesmo [Eclipse].

3.7 Adobe Fireworks

O Adobe Fireworks é uma ferramenta para criação de imagens leve e eficiente que possibilita a criação de gráficos para páginas da Web, eliminando a confusão de códigos e paletas de cores. Também se integra perfeitamente com o Photoshop, o Illustrator e o Dreamweaver [Adobe].

4 Segmentação e Classificação de sons cardíacos

Neste capítulo, descreve-se um novo algoritmo de classificação de sons cardíacos, que foi desenvolvido no âmbito do trabalho que aqui é descrito. Neste trabalho foi utilizado o dataset descrito na secção 2.2. Trata-se do Dataset B do concurso “PASCAL Classifying Heart Sounds Challenge” [Bentley, 2011] para ser possível comparar os resultados obtidos com os resultados anteriores. Como já foi referido anteriormente este dataset é constituído por 312 ficheiros com a seguinte distribuição por classes:

- Normal - 200 cases (64.1 %)
- Murmur - 66 (21.2 %)
- Extrasystole - 46 (14.7 %)

Toda a fase de pré-processamento e segmentação dos sons cardíacos foi baseada no desenvolvimento da última abordagem, descrita na secção 2.3.2. Assim, foi utilizada a técnica de segmentação através de padrões (*motifs*) com discretização baseada na representação SAX, utilizando o algoritmo MrMotif para a descoberta dos padrões (imagem 4 da Figura 9). Esta técnica para a segmentação foi a escolhida para aplicação do algoritmo de classificação desenvolvido, pelo facto nas abordagens anteriores terem sido utilizados os mesmos algoritmos de classificação e os resultados da última investigação terem sido significativamente melhores.

4.1 Algoritmo de Classificação

O algoritmo de classificação desenvolvido tem como premissa para a classificação a estratégia de descobrir automaticamente os padrões com maior frequência e mais relevantes, relacionando-os com a ocorrência sistólica (S1) e a ocorrência diastólica (S2) em ficheiros de som de sinais cardíacos.

Tal como já foi referido na secção 2.2, cada uma das três classes utilizadas na classificação (Normal (N), Murmur (M) e Extrasystole (E)) tem características diferentes e é reconhecida através dessas mesmas características. A classe do tipo Murmur é reconhecida por ter entre a sístole e diástole, o batimento de contracção cardíaca seguido do relaxamento do coração, um pequeno outro estímulo vulgarmente descrito como Murmur. Segundo especialistas o batimento cardíaco com a patologia Murmur pode ser representado por [Bentley, 2011]:

...lub..****..dub..... lub..****..dub lub..****..dub lub..****..dub ...

↑
Murmur

Ou

...lub.....dub...*****lub..... dub...*****lub dub...*****lubdub...

↑
Murmur

O batimento cardíaco com a patologia Extrasystole pode ser representado por:

.....lub.....dub..... lub.dub.....lub.lub.....dub.....

↑
Extrasystole

Ou

...lub..... dub.....lub.....dub.dub.....lub.....dub.....

↑
Extrasystole

E o batimento cardíaco pertencente á categoria normal pode ser representado por:

...lub.....dub..... lub.....dub..... lub.....dub..... lub.....dub...

4.1.1 Classificação do sinal cardíaco

Nesta secção, apresenta-se um novo algoritmo de classificação (Figura 20), que se baseia no conhecimento dos batimentos cardíacos, em particular no S1 (sístole) e S2 (diástole). Para cada som, o algoritmo começa por encontrar os padrões (motifs) mais frequentes usando a discretização SAX, já referida nas secções anteriores. No passo seguinte, tenta mapear estes padrões com os sons S1 e S2. Um coração normal é caracterizado por um número aproximadamente igual de S1 e S2 sem nenhum outro padrão relevante. Neste caso foi considerado que os dois padrões mais frequentes correspondem a S1 e a S2.

Para o algoritmo classificar um som como sendo de uma patologia Murmur (classe Murmur) pesquisa pelo maior número de padrões existentes no sinal, apresentando os três números de valor máximo encontrado, que devem ser iguais em valor. Estes três valores serão respetivamente a sístole (ou S1), a diástole (ou S2) e o Murmur encontrado entre os dois batimentos. Se o algoritmo encontrar este tipo de padrão então classifica o som como pertencente à classe Murmur.

Para a classificação do tipo de patologia Extrasystole o algoritmo pesquisa por dois padrões com valores em que o máximo é divisível por três e que o próximo valor mais elevado é a soma de duas partes do máximo, pois como podemos verificar pela descrição da patologia acima, a cada dois pares de batimento cardíaco, um deles repete-se, o que significa que a cada três batimentos de um tipo, teremos dois do outro tipo. Se os padrões encontrados tiverem estas características então o algoritmo irá classificá-los como pertencentes à classe Extrasystole.

Como o algoritmo começa por efetuar todas as verificações necessárias para a classificação das patologias, se o som cardíaco não estiver de acordo com as características de ambos os casos, então é classificado como pertencente à classe Normal.

Algorithm 1: Proposed algorithm

Input: HS : a set of heart sounds; δ, q : error thresholds
Output: C : a set of assigned class labels

```

1  $M \leftarrow$  motifs found in  $HS$ 
2 for  $s \in HS$  do
3    $m_1 \leftarrow$  most frequent motif in  $s$ 
4    $m_2 \leftarrow$  2nd most frequent motif in  $s$ 
5    $m_3 \leftarrow$  3rd most frequent motif in  $s$ 
6    $f_1 \leftarrow$  frequency of  $m_1$ 
7    $f_2 \leftarrow$  frequency of  $m_2$ 
8    $f_3 \leftarrow$  frequency of  $m_3$ 
9   if  $abs(f_1 - f_2) < \delta$  and  $f_1/f_2 > q$  then
10     $C_s \leftarrow N$ ;
11   if  $abs(f_1 - f_3) < \delta$  then
12     $C_s \leftarrow M$ ;
13   if  $abs(2f_1 - 3f_2) < \delta$  and  $f_2/f_3 > q$  then
14     $C_s \leftarrow E$ ;
15 return  $C$ 

```

Figura 13: novo algoritmo de classificação

4.1.2 Discussão de resultados

Nesta subsecção apresentam-se os resultados obtidos com o novo algoritmo de classificação.

Para avaliar os resultados obtidos com este algoritmo de classificação (coluna “Nova”, na Tabela 2 e os resultados obtidos com a abordagem anterior (coluna “Anterior”, na Tabela 2) utilizou-se o conjunto de sons não etiquetados, disponibilizados pelo Classifying Heart Sounds PASCAL Challenge [Bentley, 2011].

Tabela 2: comparação de resultados obtidos na antiga e na nova abordagem

	Anterior	Nova
Precision of Normal	0.72	0.77
Precision of Murmur	0.32	0.38
Precision of Extrastole	0.33	0.12
Sensitivity of heart problem	0.22	0.29
Specicity of heart problem	0.82	0.51
F1 score	0.35	0.37

Estes sons de teste não foram utilizados na descoberta de padrões (*motifs*) nem no desenvolvimento do algoritmo. Estes dados, permitem uma comparação não enviesada com a abordagem baseada nos Picos. Nestas experiências foram utilizados o $\delta_1=2$ e $\delta_2=2$ para *threshold* do erro.

Foram utilizadas, para a avaliação da eficiência desta abordagem de classificação, três métricas calculadas a partir dos valores de *tp* (true positives, onde positivo corresponde a classes com patologia), *fp* (false positives), *tn* (true negatives) e *fn* (false negatives). As métricas são a *precision* por classe, a *sensitivity* (ver Equação 1), *specificity* (ver Equação 2) e a medida *F1* (ver Equação 2).

$$sensitivity = \frac{tp}{tp+fn} \quad (1)$$

$$specificity = \frac{tn}{tn+fp} \quad (2)$$

$$F1 = \frac{2*specificity*sensitivity}{specificity + sensitivity} \quad (3)$$

A *precision* dá-nos o valor preditivo positivo, ou seja, a proporção de amostras que pertencem à categoria, *c*, e que estão corretamente colocadas na categoria *c*.

Como podemos observar na Tabela 2, este novo método é melhor a classificar as classes Normal e Murmur mas tem problemas em classificar a Extrasystole. Também melhorou os resultados da medida $F1$ que é uma combinação equilibrada da *sensitivity* e da *specificity*. Resultados publicados [Oliveira, 2014].

5 Aplicação móvel para classificação de sons cardíacos

O sistema informático criado no âmbito desta investigação cujo tema é “Classificação de Sons Cardíacos usando motifs” é composto por duas partes totalmente distintas, a componente de classificação, onde a cada som é aplicado o algoritmo de classificação desenvolvido e a componente aplicacional móvel que permite ao utilizador captar sons cardíacos através de um smartphone para posterior classificação.

Para a comunicação entre as duas componentes foram desenvolvidos webservices que permitem a passagem de dados da aplicação móvel para o servidor através de rede *Wi-Fi*.

A componente de servidor, que permite a classificação dos sons cardíacos, e os webservices, essenciais para a passagem de dados entre as duas componentes, foram desenvolvidos na linguagem de programação Java. A componente aplicacional móvel, que disponibiliza ao utilizador as funcionalidades necessárias para a classificação do som cardíaco foi desenvolvida na linguagem de programação móvel Android.

Nos próximos subcapítulos serão abordadas os componentes detalhadamente, bem como a arquitectura aplicacional utilizada.

5.1 Arquitectura

O funcionamento do sistema como um todo engloba um componente aplicacional móvel, um componente de classificação em servidor e webservices para a comunicação entre ambos.

Todo o processo é despoletado na *App*, onde o utilizador pode escolher a funcionalidade que lhe permite enviar dados cardíacos para classificação no servidor. Os dados são recebidos pelo webservice que executa a aplicação de servidor para a classificação do som cardíaco. No final, a classificação é enviada para a aplicação móvel, aparecendo na interface gráfica ao utilizador, como uma mensagem. Esta arquitetura tem o nome cliente-servidor. Na Figura 14, apresenta-se a imagem da arquitetura do sistema.




Figura 14: arquitectura aplicacional cliente-servidor utilizada no desenvolvimento

5.1.1 Cliente-Servidor

O termo Cliente-Servidor refere-se ao método de distribuição de aplicações computacionais através de muitas plataformas [Lee V., 2005]. Este tipo de aplicações estão divididas em duas partes, a parte que apenas chama serviços existentes para busca de informação, o cliente, e a parte que apenas responde aos pedidos realizados pelo cliente, o servidor. O servidor é comumente reconhecido como um escravo que apenas realiza os pedidos do cliente. Este modelo aplicacional permite ao utilizador aceder a dados/informação que está disponível num outro sistema computacional, podendo estar geograficamente distante. O servidor pode servir vários pedidos de diferentes clientes em simultâneo.

Algumas das características do cliente, todo o processo que solicita serviços e envia pedidos ao Servidor, são:

- O cliente é o “front-end”, permite a interação do utilizador através de uma interface gráfica
- Permite representação gráfica de dados
- É o processo activo da arquitetura
- Solicitam serviços distribuídos
- Os clientes não comunicam entre si
- Torna o processo de busca de informação transparente para o utilizador

Algumas das características do servidor (todo o processo que fornece serviços, atende pedidos, processa e responde) são:

- O servidor é o “back-end” que fornece serviços, disponíveis para qualquer cliente
- Os serviços têm por base o objectivo da aplicação
- Processo reactivo, apenas reage aquando a chegada de um pedido do cliente

- Providencia respostas aos clientes, conforme a informação pretendida e o serviço chamado
- Não comunica com outros servidores
- Responde a vários pedidos de clientes distintos em simultâneo

O funcionamento da arquitectura cliente-servidor, além do pedido do cliente e resposta do servidor, permite estabelecer uma ligação entre ambas as partes que apenas termina quando o cliente recebe a resposta ao pedido solicitado (Figura 15).

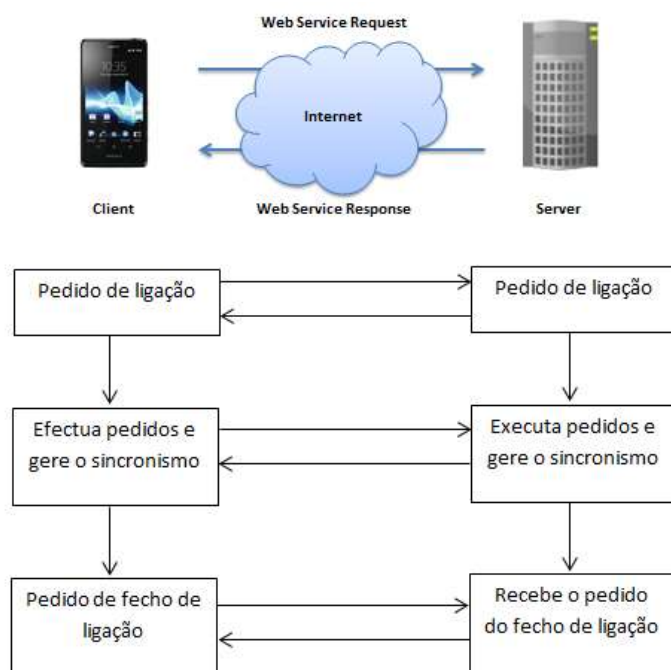


Figura 15: funcionamento da arquitectura cliente-servidor

5.2 Aplicação Móvel

Para atribuir a característica mobilidade à aplicação de servidor com o algoritmo para classificação de sons cardíacos foi desenvolvida uma aplicação móvel, que permite a captar e gravar sons cardíacos.

O algoritmo de classificação é executado com base em dados de um ficheiro do tipo CSV com valores do tipo double, que representam os valores dos picos de sinal captados. Desta forma a *App* está assente sob duas funcionalidades principais com os nomes “Record Heartbeat” e “Load File” (Figura 16).

Estas duas funcionalidades são disponibilizadas no ecrã principal e permitem ao utilizador, numa primeira fase, interagir com a aplicação. A funcionalidade “Record Heartbeat” é das duas funcionalidades, a que tem maior complexidade, no sentido que tem mais passos, ainda que todos estejam facilmente destacados e inteligíveis para o utilizador.

Após a escolha desta a funcionalidade, é apresentada ao utilizador uma interface, com pequenas indicações que o auxiliam a executar os passos necessários para captar e preparar os dados que necessitamos de enviar ao servidor.



Figura 16: interface principal da aplicação móvel

5.3 Record Heartbeat

A funcionalidade que permite ao utilizador gravar sons cardíacos tem como premissa de utilização o seguimento da ordem de passos que se iniciam com a gravação do som. Este primeiro passo tem o nome “Start Record” e exige que na sequência, quando o utilizador pretender parar a gravação, seja clicado o botão do passo seguinte com o nome “Stop Record” (Figura 17).




Figura 17: botão “Start Record” permite o início da gravação do som cardíaco

Após estes dois primeiros passos foi possível gravar o som cardíaco, sendo este o som que é tratado no terceiro passo. O terceiro passo tem duas componentes incorporadas. Numa das componentes, são aplicados filtros ao som com a finalidade da eliminação de ruído. Na outra, é feita a conversão dos valores do sinal em valores do tipo double (Figura 18).

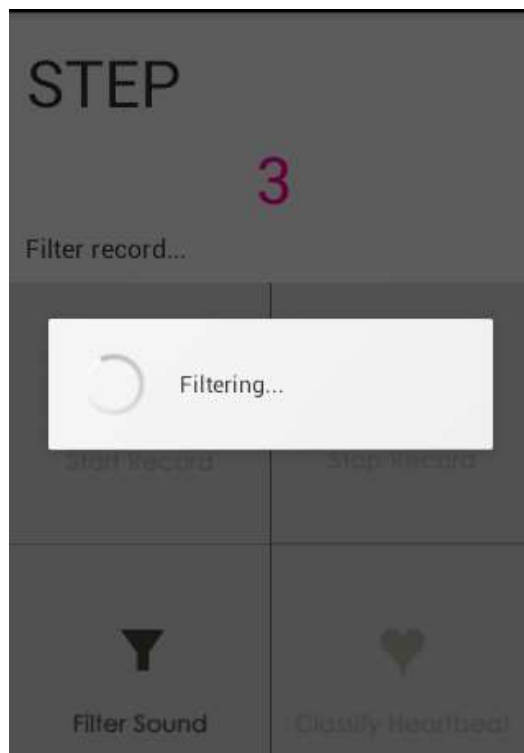


Figura 18: aplicação de filtros e normalização ao sinal cardíaco gravado

A aplicação de filtros permite reduzir o ruído, fazer a reamostragem do sinal (diminuição da taxa de amostragem do sinal), obter um sinal normalizado, o que permite por sua vez obter uma amostra para análise com valores de sinal reduzidos e mais limpo de ruído. Os filtros aplicados nesta fase são o passa-baixo e Chebyshev. É ainda calculado o envelope (Shannon) do sinal.

A aplicação dos filtros está visível no excerto de código apresentado abaixo.

```
IirFilterCoefficients coeffs =
IirFilterDesignFisher.design(FilterPassType.Lowpass,
FilterCharacteristicsType.chebyshev,
filterOrder, ripple, fcf1, fcf2);

y_norm = SignalPreparation.decimate(data, fs, limit, factor, coeffs,
nome_fx);
//faz o envelope
SignalPreparation.envelop(y_norm, fs, limit, nome_fx);

out_d.close();
```

Posteriormente a este tratamento, o quarto e último passo consiste em enviar os dados recolhidos e tratados para o servidor (Figura 19), que irá retornar ao utilizador, após a aplicação do algoritmo de classificação, o tipo de som cardíaco classificado.

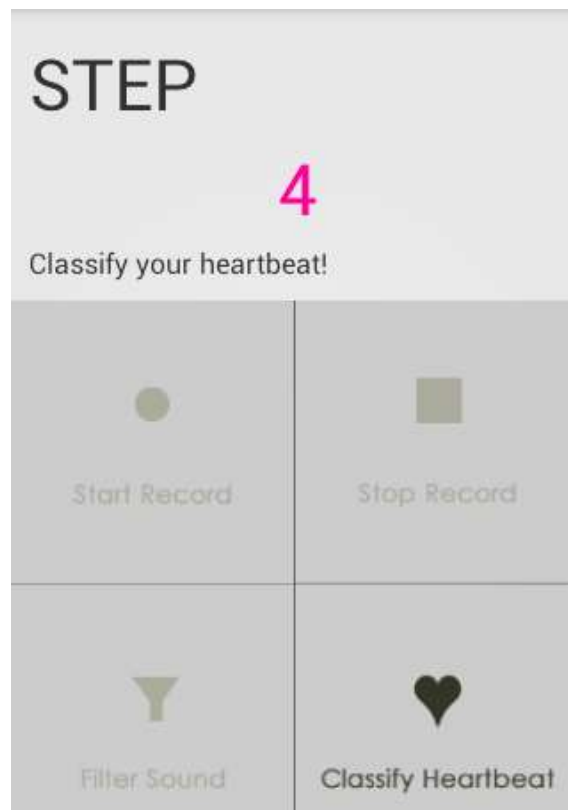


Figura 19: quarto e último passo no processo de classificação

5.3.1 Load File

A funcionalidade “Load File” permite ao utilizador classificar um som já anteriormente gravado, filtrado de ruído e tratado e com sinal convertido em valores do tipo double. Desta forma, a funcionalidade permite fazer a escolha de um ficheiro do tipo CSV que esteja no cartão de armazenamento do smartphone, numa pasta criada pela aplicação para armazenamento de ficheiros (Figura 20).

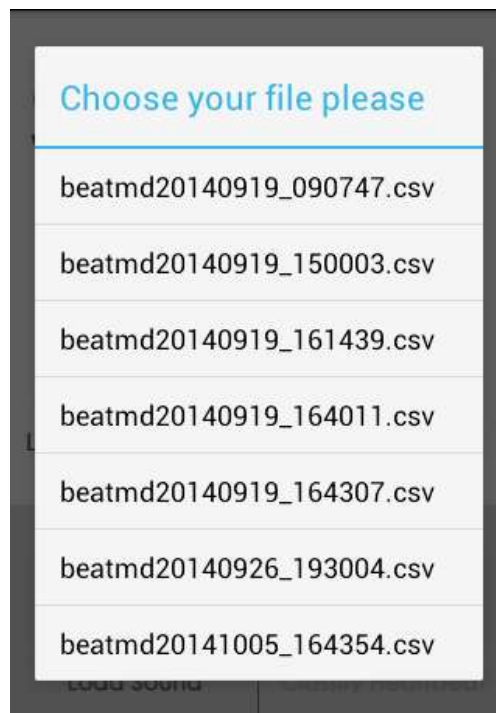


Figura 20: lista de ficheiros CSV apresentada para carregamento na aplicação

Ao escolhermos um ficheiro da lista apresentada pela aplicação, todos os valores do ficheiro serão agregados numa variável do tipo String, em que cada valor estará separado por vírgulas. Este método foi desenvolvido pelo facto de não ser possível passar ficheiros do tipo CSV como parâmetro na chamada a um serviço.

O código que representa o processo de conversão de um ficheiro do tipo CSV para uma variável do tipo String separada por vírgulas está apresentado abaixo.

```
ArrayList<String[]> toServer = readCsv(choosen);

String [] eachOne;

for(int i = 0; i<toServer.size()-1;i++){
    eachOne = toServer.get(i);
    if(i == toServer.size()-2){
        toServerClassify += eachOne[0];
    }else {
        toServerClassify += eachOne[0] + ", ";
    }
}
```

Após o carregamento do ficheiro é possível enviar os dados para classificação no servidor, de onde será retornado o valor da classificação do som cardíaco (Figura 21).

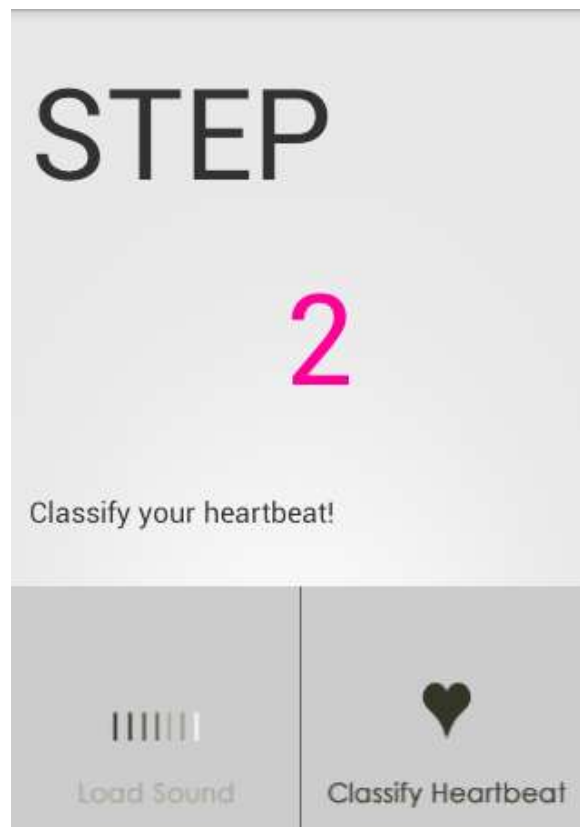


Figura 21: botão para obter a classificação do som cardíaco

O excerto de código abaixo exemplifica uma chamada do serviço de classificação ao servidor.

```
String request = "<?xml version=\"1.0\" encoding=\"UTF-8\"?><S:Envelope
xmlns:S=\"http://schemas.xmlsoap.org/soap/envelope/\" xmlns:SOAP-
ENV=\"http://schemas.xmlsoap.org/soap/envelope/\">\" +
    "<SOAP-ENV:Header/>\" +
    "<S:Body>\" +
    "<ns2:ClassifyHeartSound
xmlns:ns2=\"http://webServices/\">\" +
    "<strToServer>"+toServerClassify+"</strToServer>\" +
    "<filename>"+mChosenFile+"</filename>\" +
    "</ns2:ClassifyHeartSound>\" +
    "</S:Body>\" +
    "</S:Envelope>";

String endpoint =
"http://" + Login.ipForAllApp + ":8080/WSAppHeartBeat/HeartSoundsClassification
";

WSBackgroundTask backTask = new
WSBackgroundTask(AfterLoad.this, request, endpoint);
backTask.execute();
```

5.3.2 Webservices

Para a comunicação entre a aplicação móvel instalada no smartphone e o servidor onde se encontra o algoritmo de classificação é necessário um meio de comunicação de dados através da internet. Desta forma foi desenvolvido um webservice, que é executado no mesmo servidor onde está localizado o algoritmo de classificação, e que permite a passagem de dados entre as duas partes aplicacionais distintas.

A função deste webservice é receber um conjunto de valores do tipo double separados por vírgulas e criar um ficheiro do tipo CSV com esses mesmos valores, para posteriormente executar o algoritmo de classificação para o ficheiro criado. Esta conversão deve-se ao facto de não ser possível passar ficheiros do tipo CSV por parâmetro através de webservices, pois estes não estão preparados para receber este tipo de dados.

Após a execução do algoritmo de classificação o webservice retorna o valor do resultado da mesma à aplicação móvel, permitindo desta forma à aplicação móvel mostrar ao utilizador o resultado da classificação.

No excerto de código abaixo é apresentada a conversão de valores recebidos no parâmetro do serviço em ficheiro de extensão CSV.

```
String[] allValuesSplited = strToServer.split(",");
File beatMDataDirectory = new File("C://BeatMDataFiles//");
boolean var = false;
    if (!beatMDataDirectory.exists()) {
        var = beatMDataDirectory.mkdir();
    }
final String filename = beatMDataDirectory.toString() + "/" + fileName +
".csv";
FileWriter fw = new FileWriter(filename);
    for (int i = 0; i < allValuesSplited.length; i++) {
        try {
            fw.append("'" + allValuesSplited[i]);
        } catch (IOException e) {
            e.printStackTrace();
        }
        fw.append("\r\n");
    }
fw.close();
```

6 Conclusão

Com a motivação de facilitar o acesso de descoberta de patologias cardíacas, foi desenvolvida uma aplicação móvel capaz de gravar e tratar o som cardíaco, enviando dados para um servidor onde é feita a segmentação e classificação dos sons. O principal objectivo para o desenvolvimento desta aplicação em plataforma móvel é dotar qualquer pessoa, que tenha na sua posse um telemóvel, da capacidade de perceber se o seu coração é portador de uma patologia cardíaca. No entanto, a aplicação não pretende substituir um cardiologista, mas ser um meio de rastreio precoce.

Com o novo do algoritmo de classificação, dedicado à detecção de patologias cardíacas, obteve-se uma melhor precisão para a classe Normal e para a patologia Murmur. No entanto, a patologia Extrasystole continua a ser difícil de detectar, obtendo-se mesmo nessa classe piores resultados do que em abordagens anteriores.

Os resultados obtidos, bem como a descrição da metodologia, foram publicados em artigo nas actas da Conferência internacional IDEAS'14 [Oliveira, 2014].

O desenvolvimento da aplicação móvel permite captar sons cardíacos, filtrá-los e tratá-los para os enviar ao servidor web, onde estes são segmentados e classificados pelo algoritmo desenvolvido, o que permite que o grau de precisão obtido através da aplicação móvel seja exactamente a mesma que através do programa de servidor, pois é este que efectua a classificação na abordagem desenvolvida.

Através da utilização desta aplicação, um sistema de apoio à decisão capaz de auxiliar profissionais com conhecimento e também indivíduos sem qualquer formação na área, será possível aumentar a detecção precoce de problemas cardíacos. A aplicação poderá essencialmente reflectir uma ferramenta auxiliar para o processo de monitorização e acompanhamento, podendo futuramente incorporar dados de consultas regulares e histórico de pacientes.

6.1 Trabalho Futuro

Em termos de continuação deste trabalho foram consideradas as seguintes tarefas:

- As técnicas de pré-processamento e de segmentação dos sons cardíacos poderão ser afinadas de modo a melhorar a detecção de Extrasystole;
- O algoritmo desenvolvido deverá ser melhorado, não só para a detecção da patologia Extrasystole mas também para a patologia Murmur e corações normais;
- Na aplicação móvel também poderão ser feitos ajustes em relação às tecnologias utilizadas, principalmente no caso do dispositivo para captar sons cardíacos;
- Outras patologias que não tenham sido contempladas nesta dissertação poderão ser futuramente investigadas e incluídas na pesquisa do algoritmo de classificação;
- É necessário avaliar a utilização de um novo conjunto de dados para teste, pois toda a investigação foi realizada tendo por base dados captados em crianças de diferentes idades, o que leva à necessidade de efectuar a mesma investigação com dados captados em adultos, para validar o correcto funcionamento da segmentação e classificação dos sons cardíacos em diferentes idades;
- A aplicação móvel pode ser desenvolvida também para outras plataformas, tais como o iOS e o Windows Phone, permitindo assim o alargamento da utilização da mesma para outros grupos de utilizadores e desta forma para uma maior escala de uso.

7 Referências

- [Babaei, 2009] S. Babaei and A. Geranmayeh. Heart sound reproduction based on neural network classification of cardiac valve disorders using wavelet transforms of pcg signals. *Comp. in Bio. and Med.*, 39(1):8-15, 2009.
- [Bentley, 2011] P. Bentley, G. Nordehn, M. Coimbra, and S. Mannor. The PASCAL Classifying Heart Sounds Challenge 2011 (CHSC2011) Results. www.peterjbentley.com/heartchallenge, 2011
- [Breiman, 2001] L. Breiman. Random forests. *Machine Learning*, 45(1):5-32, 2001.
- [Castro, 2010a] N. Castro and P. J. Azevedo. Multiresolution Motif Discovery in Time Series. In *SDM*, pages 665-676, 2010.
- [Castro, 2010b] N. Castro. Multiresolution motif discovery in time series website. <http://www.di.uminho.pt/~castro/mrmotif>. [último acesso: Out 2014]
- [Ferreira, 2006] P. G. Ferreira, P. J. Azevedo, C. G. Silva, and R. M. M. Brito. Mining approximate motifs in time series. In *Discovery Science*, pages 89-101, 2006.
- [Gomes, 2012] <http://www.peterjbentley.com/heartworkshop/challengepaper1.pdf> [último acesso: Out 2014]
- [Gomes, 2013a] E. F. Gomes, P. J. Bentley, E. Pereira, M. Coimbra, and Y. Deng. Classifying heart sounds - approaches to the pascal challenge. In D. Stacey, J. Solé-Casals, A. L. N. Fred, and H. Gamboa, editors, *HEALTHINF*, pages 337-340. SciTePress, 2013.
- [Gomes, 2013b] E. F. Gomes, A. M. Jorge, and P. J. Azevedo. Classifying heart sounds using multiresolution time series motifs: an exploratory study. In B. C. Desai, A. M. de Almeida, and S. P. Mudur, editors, *C3S2E*, 23-30. ACM, 2013.
- [Gomes, 2014] Elsa Ferreira Gomes, Alípio Mário Jorge, Paulo J. Azevedo: Classifying heart sounds using SAX motifs, random forests and text mining techniques. *IDEAS 2014*: 334-337
- M. W. Groch, J. R. Domnanovich, and W. D. Erwin.

- [Groch, 1992] A new heart-sounds gating device for medical imaging. IEEE Transactions on Biomedical Engineering, 39:307-310, 1992.
- [Gupta, 2007] C. N. Gupta, R. Palaniappan, S. Swaminathan, and S. M. Krishnan. Neural network classification of homomorphic segmented heart sounds. Applied Soft Computing, 7:286-297, 2007.
- [Gupta, 2005] C. N. Gupta, R. Palaniappan, S. Rajan, S. Swaminathan, and S. M. Krishnan. Segmentation and classification of heart sounds. In Canadian Conference on Electrical and Computer Engineering, pages 1674-1677, 2005.
- [Heart, 2014] <http://www.texasheart.org/HIC/Anatomy/systole.cfm> acedido em 07/10/14.
- [Karnath, 2002] B. Karnath and W. Thornton. Auscultation of the heart. Hospital Physician, 38(9):39-43, sep. 2002
- [Karraz, 2006] G. Karraz and G. Magenes. Automatic Classification of Heartbeats using Neural Network Classifier based on a Bayesian Framework. In Annual International Conference of the IEEE Engineering in Medicine and Biology Society, pages 4016-4019, 2006.
- [Kampouraki, 2009] A. Kampouraki, G. Manis, and C. Nikou. Heartbeat Time Series Classification With Support Vector Machines. IEEE Transactions on Information Technology in Biomedicine, 13:512-518, 2009.
- [Kao, 2011] W.-C. Kao, L.-W. Cheng, C.-Y. Chien, and W.-K. Lin. Robust brightness measurement and exposure control in real-time video recording. IEEE T. Instrumentation and Measurement, 60(4):1206-1216, 2011.
- [Kumar, 2006] D. Kumar, R. Carvalho, M. Antunes, R. Gil, J. Henriques, and L. Eugenio. A New Algorithm for Detection of S1 and S2 Heart Sounds. In International Conference on Acoustics, Speech, and Signal Processing, volume 2, 2006.
- [Liang, 1997] H. Liang, S. Lukkarinen, and I. Hartimo. Heart sound segmentation algorithm based on heart sound envelopogram. In Computers in Cardiology 1997, pages 105-108, Sep 1997.
- [Lin, 2002] J. Lin, E. Keogh, S. Lonardi, and P. Patel. Finding motifs in time series. In Proceedings of the 2nd Workshop on Temporal Data Mining, pages 53-68, 2002.
- [Marques, 2013] N. Marques, R. Almeida, A. Rocha, and M. Coimbra. Exploring the stationary wavelet transform detail coefficients for detection and identification of the S1 and S2 heart sounds. In Computing in Cardiology Conference (CinC), 2013, pages 891-894, Sept 2013.
- [Oliveira, 2014] Soraia Cruz Oliveira, Elsa Ferreira Gomes, Alípio Mário Jorge: Heart sounds classification using motif based segmentation. IDEAS 2014: 370-371
- [Palm, 2010] Palm, D., Burns, S., Pasupathy, T., Deip, E., Blair, B., Flynn, M., Drewek, A., Sjostrand, M., Stephenson, B., and Nordehn, G. (2010). Artificial Neural Network Analysis of Heart Sounds Captured From an Acoustic Stethoscope and Emailed Using iStethoscopePro. Journal of Medical Devices, 4(2):027531+.
- [Pereira, 2011] D. Pereira, F. Hedayioglu, R. Correia, T. Silva, I. Dutra, F. Almeida, S. Mattos, and M. Coimbra. Digiscope - unobtrusive collection and annotating of

auscultations in real hospital environments. In Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE, pages 1193-1196, 30 2011-sept. 3 2011.

- [Strunic, 2007] S. L. Strunic, F. Rios-Gutierrez, R. Alba-Flores, G. Nordehn, and S. Burns. Detection and Classification of Cardiac Murmurs Using Segmentation Techniques and Artificial Neural Networks. In IEEE Symposium on Computational Intelligence and Data Mining, pages 128-133, 2007.
- [Witten, 2005] Witten, I. H. and Frank, E. (2005). Data Mining: Practical Machine Learning Tools and Techniques.
- [Yankov, 2007] D. Yankov, E. J. Keogh, J. Medina, B. Y. chi Chiu, and V. B. Zordan. Detecting time series motifs under uniform scaling. In P. Berkhin, R. Caruana, and X. Wu, editors, KDD, pages 844{853. ACM, 2007.
- [Lee V., 2005] Lee, Valentino. Aplicações móveis: arquitetura, projecto e desenvolvimento, pages 23-36, 2005

Referências URL:

- [Android] Disponível em <http://developer.android.com/about/index.html>; Último acesso em Out. 2014
- [Oracle] Disponível em <https://www.java.com/en/>; Último acesso em Out. 2014
- [Maven] Disponível em <http://maven.apache.org/>; Último acesso em Out. 2014
- [Apache] Disponível em <http://maven.apache.org/what-is-maven.html>; Último acesso em Out. 2014
- [W3Scholl] Disponível em <http://www.w3schools.com/webservices/>; Último acesso em Out. 2014
- [Netbeans] Disponível em <http://java.about.com/od/i/g/ide.htm>; Último acesso em Out. 2014
- [Developer] Disponível em <http://developer.android.com/tools/help/adt.html>; Último acesso em Out. 2014
- [Eclipse] Disponível em <https://www.eclipse.org/home/index.php>; Último acesso em Out. 2014
- [Adobe] Disponível em <https://creative.adobe.com/pt/products/fireworks>; Último acesso em Out. 2014
- [Unborn] Disponível em: <http://www.betterbabydeals.com.au/products/baby-care/unborn-heart-fetal-doppler/>; Último acesso em Out. 2014.
- [Device] Disponível em: <http://www.jumpingbabyjacks.com/webshaper/store/viewProd.asp?pkProductItem=425>; Último acesso em Out. 2014.
- [Matlab] Matlab version 7.10.0 (R2010a). The MathWorks Inc., Natick, Massachusetts.

Heart Sounds Classification using Motif based Segmentation

Soraia Cruz Oliveira

ISEP/IPP-School of Engineering, Polytechnic of Porto, Portugal
soraia.cruz86@gmail.com

Elsa Ferreira Gomes

GECAD- Knowledge Engineering and Decision Support Research Center
ISEP/IPP-School of Engineering, Polytechnic of Porto, Portugal
efg@isep.ipp.pt

Alípio M. Jorge

LIAAD-INESC TEC
DCC-FCUP, Universidade do Porto, Portugal
amjorge@fc.up.pt

ABSTRACT

In this paper we describe an algorithm for heart sound classification (classes Normal, Murmur and Extra-systole) that is based on the discretization of sound signals using the SAX (Symbolic Aggregate Approximation) representation. The general strategy is to automatically discover relevant top frequent motifs and relate them with the occurrence of systolic (S1) and diastolic (S2) sounds in the audio signals. The algorithm was tuned using motifs generated from a collection of audio signals obtained from a clinic trial in a hospital using the digital stethoscope DigiScope. Validation was performed on a separate set of unlabeled audio signals. Results indicate ability to improve the precision of the classification of the classes Normal and Murmur.

Keywords

Heart sound classification, motif discovery, time series analysis, SAX.

1. INTRODUCTION

This work is part of an ongoing effort to define algorithms that are able to perform the first level of screening of cardiac pathologies in a Hospital environment by a doctor, using for example a digital stethoscope. Such an algorithm performs automatic classification of heart sounds, by assigning a new sound to a clinical condition (class). In this case we consider three classes: Normal (N), Murmur (M) and Extrasystole (E). Heart sound signals of a normal heart have two main components: the first heart sound, S1 (or lub), corresponding to the systolic period, and the second heart

sound, S2 (or dub), the diastolic period [4]. In the Normal category there are normal, healthy heart sounds. A normal heart sound has a clear 'lub dub, lub dub' pattern, with the time from 'lub' to 'dub' shorter than the time from 'dub' to the next 'lub'. In the Murmur category, the heart murmurs sound as though there is a 'whooshing, roaring, rumbling, or turbulent fluid' noise in one of two temporal locations: (1) between 'lub' and 'dub', or (2) between 'dub' and 'lub'. They can be a symptom of many heart disorders, some serious. One of the things that confuses non-medically trained people is that murmurs happen between lub and dub or between dub and lub; not on lub and not on dub. Finally, the Extrasystole category sounds may appear occasionally and can be identified because there is a heart sound that is out of rhythm involving extra or skipped heartbeats, e.g. a 'lub-lub dub' or a 'lub dub-dub'. Notice that an extrasystole may not be a sign of disease. It can happen normally in an adult and can be very common in children. However, in some situations extrasystoles can be caused by heart diseases. In practice, captured sounds may contain a variety of background noises. They may also contain occasional random noise corresponding to breathing, or brushing the microphone against clothing or skin [1].

One common step previous to classification is segmentation, where S1 and S2 sound segments are located within the audio sequence. Being time series, recorded cardiac sounds can be processed to identify frequent motifs (sub-sequences). In this paper we use a SAX (Symbolic Aggregate Approximation) based approach to discover frequent motifs in heart sounds and then try to identify which motifs correspond to the sounds S1 and S2. This is done by aligning the frequencies of the discovered motifs with the expected frequencies of S1 and S2 for each different class. We call this alignment process 'motif-based segmentation'.

We have fine tuned our classification algorithm using a dataset prepared for the PASCAL Classifying Heart Sounds Challenge (dataset B). This dataset consists of 312 auscultations gathered using the DigiScope Collector system [6] deployed in the Maternal and Fetal Cardiology Unit of the Real Hospital Português (RHP) in Recife Brazil. Each auscultation consists of 6 to 10 seconds recorded for each of the

Permission to make digital or hard copies of all or part of this work for personal or classroom use is granted without fee provided that copies are not made or distributed for profit or commercial advantage and that copies bear this notice and the full citation on the first page. To copy otherwise, to republish, to post on servers or to redistribute to lists, requires prior specific permission and/or a fee.

IDEAS14 July 7-9, Porto [Portugal]

Editor: Bipin C. DESAI

Copyright 2014 ACM 978-1-4503-1976-8/12/06 ...\$15.00.

four standard cardiac auscultation spots in children. Relevant patient and auscultation information was also annotated by clinicians from RHP using the DigiScope Collector system, including the presence of abnormal sounds such as murmurs. The 3 classes Normal, Murmur and Extrasystole have the following distribution: Normal - 200 cases (64.1 %); Murmur - 66 (21.2 %); Extrasystole - 46 (14.7 %).

2. PREVIOUS APPROACHES

In previous works, we have used machine learning methods to induce classifiers for heart sounds. The general procedure was to profile the heart sounds using a set of characterizing attributes. In our first approach we have proposed a peak detection methodology [2]. Our algorithm identified the peaks (S1 and S2) on the envelope calculated using the normalized average Shannon energy [5] (Image 2 of Figure 1). Attributes were defined in terms of the averages and standard deviations of the distances between prominent local maxima in the time series.

In a second approach we have used the SAX-based Multiresolution Motif Discovery, MrMotif, for Heart Sound Classification [3]. Motif discovery allows the surveying of frequent local patterns (motifs) in the time series, not necessarily peaks. Here, attributes were the motifs found characterized by the frequency of each motif in each sound. A motif in a time series is a frequently repeated subsequence (frequent pattern). Image 4 of Figure 1 shows an example of a motif.

3. OUR ALGORITHM

Our classification algorithm is based on the knowledge of the heart beats, particularly on the first sound, S1 (or lub) and the second sound, S2 (or dub). Algorithm 1 starts by discovering the most frequent motifs using SAX discretization. Then, it obtains the frequencies of the three most frequent motifs. In the next steps it tries to map these motifs with the S1 and S2 sounds. A Normal heart sound is characterized by an approximately equal number of S1 and S2 without any other relevant motif. In this case we assume that the two most frequent motifs correspond to S1 and S2. If we have three top equally frequent motifs it is likely that we have a Murmur heart sound. Finally, the Extrasystole class has three S2 sounds for each two S1 sounds.




Figure 1: Image 1: Original signal; Image 2: Envelope and peaks; Image 3: Original signal and peaks; Image 4: One exemplar motif is shown in thicker line (alternating blue and red) overimposed on the original timeseries (x-Time/y-Amplitude).

Algorithm 1: Proposed algorithm

Input: HS: a set of heart sounds; δ, q : error thresholds
Output: C: a set of assigned class labels

```

1 M  $\leftarrow$  motifs found in HS
2 for s  $\in$  HS do
3   m1  $\leftarrow$  most frequent motif in s
4   m2  $\leftarrow$  2nd most frequent motif in s
5   m3  $\leftarrow$  3rd most frequent motif in s
6   f1  $\leftarrow$  frequency of m1
7   f2  $\leftarrow$  frequency of m2
8   f3  $\leftarrow$  frequency of m3
9   if abs(f1 - f2) <  $\delta$  and f1/f2 > q then
10    Cs  $\leftarrow$  N;
11   if abs(f1 - f3) <  $\delta$  then
12    Cs  $\leftarrow$  M;
13   if abs(2f1 - 3f2) <  $\delta$  and f2/f3 > q then
14    Cs  $\leftarrow$  E;
15 return C
```

4. RESULTS

Evaluation was performed on a set of unlabeled sounds made also available by the Pascal challenge. These test sounds were not used for motif discovery. They allow an unbiased comparison with the previous peak-based approach. In our experiments we have used $\delta = 2$ and $q = 1.2$ for the error thresholds. We used, for the assessment of the effectiveness of our classification approach, three metrics calculated from the tp (true positives, where positives corresponds to disease classes), fp (false positives), tn (true negatives) and fn (false negatives) values. The metrics are precision per class, sensitivity (tp/(tp + fn)), specificity (tn/(tn + fp)) and F₁ score (2 * specificity * sensitivity / (specificity + sensitivity)). Precision gives us the positive predictive value (the proportion of samples that belong in category c that are correctly placed in category c).

Table 1: Evaluation for Dataset using the previous and the new approach

	Previous	New
Precision of Normal	0.72	0.77
Precision of Murmur	0.32	0.38
Precision of Extrastole	0.33	0.12
Sensitivity of heart problem	0.22	0.29
Specificity of heart problem	0.82	0.51
F ₁ score	0.35	0.37

As we can see in Table 1, our new method is better in classifying Normal and Murmur classes but it has problems in classifying the Extrasystole heart beats.

5. CONCLUSION AND FUTURE WORK

In this paper, we have proposed an algorithm for automatically discover relevant top frequent motifs and relate them with the occurrence of systolic (S1) and diastolic (S2) sounds in the audio signals (without ECG reference). We also compare the obtained results with the results obtained with our previous approach (winning methodology for the

Classifying Heart Sounds PASCAL Challenge). This new algorithm is based on the discretization of sound signals using the SAX representation. The algorithm was tuned using motifs generated from a collection of audio signals obtained from a clinic trial in hospitals using the digital stethoscope DigiScope. Validation was performed on a separate set of unlabeled audio signals. Results indicate ability to improve the precision with respect to the classes Normal and Murmur as well the F_1 measure.

We will continue the exploration of motif based heart sound characterization and improve our algorithm, mainly, in the characterization the Extrasystole class. This class is very hard to detect by any technique applied on this data set. We will also exploit these algorithm's ideas as a basis for the definition of attributes to be used in machine learning methods.

6. ACKNOWLEDGMENTS

This work is supported by FEDER Funds through the "Programa Operacional Factores de Competitividade - COMPETE" program and by National Funds through FCT "Fundação para a Ciência e a Tecnologia" under the project: FCOMP-01-0124-FEDER- PEst-OE/EEI/UI0760/2014

7. REFERENCES

- [1] P. Bentley, G. Nordehn, M. Coimbra, and S. Mannor. The PASCAL Classifying Heart Sounds Challenge 2011 (CHSC2011) Results. www.peterjbentley.com/heartchallenge, 2011.
- [2] E. F. Gomes, P. J. Bentley, E. Pereira, M. Coimbra, and Y. Deng. Classifying heart sounds - approaches to the pascal challenge. In D. Stacey, J. Solé-Casals, A. L. N. Fred, and H. Gamboa, editors, HEALTHINF, pages 337–340. SciTePress, 2013.
- [3] E. F. Gomes, A. M. Jorge, and P. J. Azevedo. Classifying heart sounds using multiresolution time series motifs: an exploratory study. In B. C. Desai, A. M. de Almeida, and S. P. Mudur, editors, C3S2E, pages 23–30. ACM, 2013.
- [4] C. N. Gupta, R. Palaniappan, S. Swaminathan, and S. M. Krishnan. Neural network classification of homomorphic segmented heart sounds. *Applied Soft Computing*, 7:286–297, 2007.
- [5] H. Liang, S. Lukkarinen, and I. Hartimo. Heart sound segmentation algorithm based on heart sound envelopogram. In *Computers in Cardiology 1997*, pages 105–108, Sep 1997.
- [6] D. Pereira, F. Hedayioglu, R. Correia, T. Silva, I. Dutra, F. Almeida, S. Mattos, and M. Coimbra. Digiscope - unobtrusive collection and annotating of auscultations in real hospital environments. In *Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE*, pages 1193 –1196, 30 2011-sept. 3 2011.